

AUTOMATIZAÇÃO DO YOLO PARA ANÁLISE DA MÉTRICA DE ÁREA FOLIAR SOB DIFERENTES ESPÉCIES VEGETAIS

AUTOMATION OF YOLO FOR ANALYSIS OF FOLIAR AREA METRICS UNDER DIFFERENT PLANT SPECIES

AUTOMATIZACIÓN DE YOLO PARA EL ANÁLISIS DE LA MÉTRICA DEL ÁREA FOLIAR EM DIFERENTES ESPECIES VEGETALES

Juliana Carneiro Vieira¹, Ana Julia Andrade Batista Filha², Polyanna Pereira Fonseca³, Walter Júnior Jovencio de Faria⁴, Eliane Vieira Rosa⁵, José Luís Rodrigues Martins⁶, Vilson Soares de Siqueira⁷, Flávia Oliveira Abrão Pessoa⁸

DOI: 10.54899/dcs.v23i87.4330

Recibido: 23/01/2026 | **Aceptado:** 27/01/2026 | **Publicación en línea:** 09/02/2026.

RESUMO

A automatização de plataformas no âmbito da agricultura de precisão, buscam integrar eficiência computacional, rigor estatístico e aplicabilidade agrônômica, contribuindo para o avanço das metodologias não destrutivas de avaliação do crescimento vegetal e para a consolidação do uso da inteligência artificial, visto a escassez de protocolos voltados a métrica foliar de forma objetiva, prática e rápida, um fator determinante em pesquisas de cunho científico ou no cotidiano para inferências agrônômicas, à exemplo, verificação de doenças foliares. O objetivo deste estudo, é adaptar a arquitetura do YOLO para automatização em análise de imagens da área foliar de diferentes espécies vegetais, em que ao mesmo tempo possa ser acessível e de fácil aplicação. A metodologia baseou-se em um estudo experimental usando o modelo YOLO11, na obtenção e organização dos dados para automação, anotação e pré-processamento dos dados adquiridos. Foram avaliados: melhor desempenho de parâmetros (M), tempo de treinamento (h), tempo de inferência (ms), Mask mAP50-95, precisão (P) e recall (R). Os resultados demonstraram que a detecção e segmentação automatizada de folhas baseadas no YOLO, tiveram como melhor

¹ Mestranda em Irrigação no Cerrado, Ciências Agrárias I, Instituto Federal de Educação, Ciência e Tecnologia Goiano (IFGoiano) – campus Ceres, Ceres, Goiás, Brasil. E-mail: juliana.vieira.biologa@gmail.com

² Mestranda em Irrigação no Cerrado, Ciências Agrárias I, Instituto Federal de Educação, Ciência e Tecnologia Goiano (IFGoiano) – campus Ceres, Ceres, Goiás, Brasil. E-mail: anajulia.abfilha@gmail.com

³ Mestranda em Irrigação no Cerrado, Ciências Agrárias I, Instituto Federal de Educação, Ciência e Tecnologia Goiano (IFGoiano) – campus Ceres, Ceres, Goiás, Brasil. E-mail: polyanna.fonseca06@gmail.com

⁴ Mestrando em Irrigação no Cerrado, Ciências Agrárias I, Instituto Federal de Educação, Ciência e Tecnologia Goiano (IFGoiano) – campus Ceres, Ceres, Goiás, Brasil. E-mail: walterjun@gmail.com

⁵ Doutora em Ciências e Tecnologias em Saúde, Nanotecnologia Aplicada à Saúde, Faculdade de Ciências e Tecnologias em Saúde, Universidade de Brasília (FCE - UNB), Ceres, Goiás, Brasil.
E-mail: eliane.vieira@ifgoiano.edu.br

⁶ Doutor em Ciências Biológicas, Universidade Federal de Goiás (UFG), Ceres, Goiás, Brasil.
E-mail: jose.martins@docente.unievangelica.edu.br

⁷ Doutor em Ciência da Computação, Universidade Federal de Goiás (UFG), Ceres, Goiás, Brasil.
E-mail: vilson.soares@ifgoiano.edu.br

⁸ Doutora em Zootecnia, Nutrição Animal, Universidade Federal de Minas Gerais (UFMG), Ceres, Goiás, Brasil.
E-mail: flavia.abrao@ifgoiano.edu.br

resposta o modelo YOLO11s para estimativa de área foliar em diferentes espécies vegetais, apresentando $M=10$, $h=0,96$, $ms=8,5$, Mask mAP50-95 de 0,956, $P=0,980$ e $R=0,962$. Portanto, a escolha do modelo final busca uma análise holística, abordando não apenas a capacidade da rede neural, mas também os fatores operacionais: resolução das imagens, o custo computacional e a finalidade agrônômica da aplicação, além do tempo resposta de retorno a leitura da área foliar.

Palavras-chave: Agricultura de Precisão. Área Foliar. Modelo de Segmentação. *Software*. YOLO11s.

ABSTRACT

The automation of platforms in the field of precision agriculture seeks to integrate computational efficiency, statistical rigor, and agronomic applicability, contributing to the advancement of non-destructive methodologies for plant growth assessment and the consolidation of the use of artificial intelligence, given the scarcity of protocols focused on leaf metrics in an objective, practical, and rapid manner, a determining factor in scientific research or in everyday agronomic inferences, such as the detection of leaf diseases. The objective of this study is to adapt the YOLO architecture for automation in image analysis of the leaf area of different plant species, which at the same time can be accessible and easy to apply. The methodology was based on an experimental study using the YOLO11 model, in obtaining and organizing data for automation, annotation, and preprocessing of the acquired data. The following were evaluated: best parameter performance (M), training time (h), inference time (ms), Mask mAP50-95, precision (P), and recall (R). The results showed that automated leaf detection and segmentation based on YOLO had the best response with the YOLO11s model for estimating leaf area in different plant species, with $M=10$, $h=0.96$, $ms=8.5$, Mask mAP50-95 of 0.956, $P=0.980$, and $R=0.962$. Therefore, the choice of the final model seeks a holistic analysis, addressing not only the capacity of the neural network but also operational factors: image resolution, computational cost, and the agronomic purpose of the application, in addition to the response time for reading the leaf area.

Keywords: Precision Agriculture. Leaf Area. Segmentation Model. Software. YOLO11s.

RESUMEN

La automatización de plataformas en el ámbito de la agricultura de precisión busca integrar la eficiencia computacional, el rigor estadístico y la aplicabilidad agronómica, contribuyendo al avance de las metodologías no destructivas de evaluación del crecimiento vegetal y a la consolidación del uso de la inteligencia artificial, dada la escasez de protocolos orientados a la métrica foliar de forma objetiva, práctica y rápida, un factor determinante en la investigación científica o en el día a día para las inferencias agronómicas, como, por ejemplo, la verificación de enfermedades foliares. El objetivo de este estudio es adaptar la arquitectura de YOLO para la automatización en el análisis de imágenes del área foliar de diferentes especies vegetales, de manera que sea accesible y fácil de aplicar. La metodología se basó en un estudio experimental utilizando el modelo YOLO11, en la obtención y organización de los datos para la automatización, anotación y preprocesamiento de los datos adquiridos. Se evaluaron: mejor rendimiento de los parámetros (M), tiempo de entrenamiento (h), tiempo de inferencia (ms), Mask mAP50-95, precisión (P) y recuperación (R). Los resultados demostraron que la detección y segmentación automatizada de hojas basada en YOLO tuvo como mejor respuesta el modelo YOLO11s para la estimación del área foliar en diferentes especies vegetales, con $M=10$, $h=$

0,96, ms = 8,5, Mask mAP50-95 de 0,956, P= 0,980 y R= 0,962. Por lo tanto, la elección del modelo final busca un análisis holístico, abordando no solo la capacidad de la red neuronal, sino también los factores operativos: resolución de las imágenes, el coste computacional y la finalidad agronómica de la aplicación, además del tiempo de respuesta de retorno a la lectura del área foliar.

Palabras clave: Agricultura de Precisión. Área Foliar. Modelo de Segmentación. Software. YOLO11s.



Esta obra está bajo una [Licencia Creative Commons Atribución- NoComercial 4.0 Internacional](https://creativecommons.org/licenses/by-nc/4.0/)

INTRODUÇÃO

A inteligência artificial (IA) tem sido progressivamente incorporada ao monitoramento, manejo e melhoramento de culturas agrícolas, integrando dados provenientes de sensores, imagens digitais e ferramentas computacionais com o objetivo de otimizar o uso de recursos e apoiar a tomada de decisão no campo. Dentre as aplicações emergentes da IA na agricultura, destacam-se as análises automatizadas de imagens, as quais possibilitam a coleta de dados de forma mais rápida, precisa e em larga escala, reduzindo a dependência de métodos manuais e destrutivos. Nesse contexto, a adoção de plataformas de código aberto e de fácil acesso torna-se estratégica, especialmente para garantir a viabilidade da implementação dessas tecnologias em pesquisas agrônomicas e sistemas produtivos a longo prazo (SUAREZ; BLASER; SUTTON, 2025; BÖKLE *et al.*, 2025).

As folhas constituem indicadores fundamentais do crescimento e do estado fisiológico das plantas, uma vez que estão diretamente relacionadas aos processos de fotossíntese, transpiração e acúmulo de biomassa. A área foliar, em particular, representa um parâmetro-chave para a avaliação do desempenho vegetal, pois está associada à capacidade de interceptação luminosa, ao balanço hídrico e, conseqüentemente, à produtividade das culturas. Assim, a mensuração precisa da área foliar é amplamente utilizada em estudos de fisiologia vegetal, fenotipagem, manejo agrícola e programas de melhoramento genético (SUAREZ; BLASER; SUTTON, 2025).

Tradicionalmente, a determinação da área foliar tem sido realizada por meio de uma variedade de técnicas que podem ser classificadas em métodos diretos e indiretos. Os métodos diretos, embora considerados precisos, incluem abordagens destrutivas, como o uso de

planímetros e métodos gravimétricos, que exigem a remoção do material vegetal e inviabilizam o acompanhamento longitudinal da mesma planta. Já os métodos diretos instrumentais, como medidores portáteis de área foliar, apresentam alta acurácia, porém impõem restrições econômicas devido ao elevado custo de aquisição. Por sua vez, os métodos indiretos, baseados em medições lineares ou equações alométricas, são de baixo custo e não destrutivos, mas dependem fortemente da espécie, do estágio fenológico e do modelo matemático adotado, o que pode comprometer a precisão quando aplicados a diferentes condições experimentais (SCHRADER *et al.*, 2021; MU *et al.*, 2024).

Ferramentas digitais vêm sendo empregadas para a estimativa da área foliar, com destaque para *softwares* de análise de imagens. Entre eles, o *ImageJ*, desenvolvido pelo *National Institutes of Health* (NIH), destacando-se por ser uma plataforma de código aberto amplamente utilizada em diversas áreas das ciências biológicas, permitindo a expansão de funcionalidades por meio de *macros* e *plugins*. Embora essas ferramentas tornem a medição da área foliar mais acessível, econômica e reprodutível, ainda apresentam limitações associadas à qualidade da imagem, à preparação da amostra e à necessidade de etapas manuais, o que restringe sua aplicação em análises de alta vazão (YU *et al.*, 2020).

O uso de arquiteturas de *Deep Learning*, como o modelo *You Only Look Once* (YOLO), tem se mostrado promissor para a detecção e segmentação automatizada de folhas em imagens digitais. Versões modernas dessa arquitetura permitem a identificação rápida e precisa de objetos, superando limitações dos métodos tradicionais ao possibilitar análises não destrutivas, com mínima intervenção humana e elevado rendimento computacional. A segmentação de folhas baseada em YOLO envolve múltiplas camadas convolucionais capazes de extrair características hierárquicas da imagem, desde contornos simples até padrões morfológicos complexos, favorecendo a delimitação precisa da área foliar mesmo em cenários com variações de forma, tamanho e espécie vegetal (RIBEIRO *et al.*, 2025; SALKA *et al.*, 2025).

Apesar dos avanços recentes na aplicação de modelos de visão computacional para a estimativa da área foliar, ainda há escassez de protocolos automatizados, não destrutivos e estatisticamente validados que sejam simultaneamente precisos, acessíveis e aplicáveis a diferentes espécies vegetais sob um mesmo *framework* computacional. A ausência de padronização metodológica limita a comparabilidade entre estudos e dificulta a adoção ampla dessas tecnologias em pesquisas agrônomicas e programas de fenotipagem vegetal de alta vazão.

Por conseguinte, o presente estudo objetiva-se pela relevância de conduzir e adaptar a arquitetura YOLO para a automatização da análise de imagens visando à mensuração da área foliar, estabelecendo um protocolo robusto, acessível e de fácil aplicação.

REFERENCIAL TEÓRICO

O IAF (índice de área foliar) é utilizado como parâmetro que analisa o desenvolvimento e crescimento de plantas. Explorar esse parâmetro mostra a capacidade que as plantas possuem para se desenvolver em determinado espaço (LUIZ, 2025). A equação de *Montgomery* (EM) propõe que a área foliar (A) pode ser estimada a partir da proporcionalidade entre o comprimento (C) e a largura (L) da folha, configurando-se como um método não destrutivo amplamente aplicável a espécies de folhas largas. Para a obtenção dos parâmetros C e L, as abordagens atuais podem ser classificadas em duas categorias principais: aquelas que utilizam recursos de reconhecimento computacional e aquelas baseadas em medições manuais (MU *et al.*, 2024).

Segundo Yu *et al.* (2020), a medição da área foliar pode ser dividida em métodos diretos e indiretos. Os métodos diretos buscam a medição física da folha. Dentre eles, os métodos destrutivos, que incluem o uso do planímetro ou o método gravimétrico, exigindo secagem e balança de precisão, ambos demandando a remoção do material vegetal, o que inviabiliza o monitoramento longitudinal da mesma amostra. Já os métodos diretos instrumentais, como os medidores portáteis de área foliar, oferecem alta acurácia, considerados não destrutivos, mas, impõem barreiras financeiras devido ao alto custo de aquisição.

Por outro lado, os métodos indiretos, como a utilização de dimensões lineares, baseiam-se em equações de regressão alométricas pré-estabelecidas (FANOURLAKIS; KAZAKOS; NEKTARIOS, 2021). Embora sejam não destrutivos e de baixo custo, a acurácia é dependente do modelo e da espécie, introduzindo erros substanciais ao serem aplicados a diferentes estágios fenológicos ou a cultivares distintas. Alternativas digitais, como *softwares* proprietários, oferecem alta precisão, mas também estão sujeitas às mesmas barreiras de acesso e custo (MU *et al.*, 2024). A necessidade de um protocolo que seja simultaneamente não destrutivo, preciso, de baixo custo e facilmente replicável em qualquer laboratório de Agronomia, é, portanto, uma busca constante e vital.

Estudos com o *software* do modelo *You Only Look Once* (YOLO) estão sendo utilizados para detecção de doenças foliares, como em melancia (MADADUM NASIR;


HARUEHANSAPONG, 2025), amendoim (BAI *et al.*, 2025) e maçãs (ZHAO; YANG; ZHANG, 2025), sendo implementados com combinados de conjunto de dados, como exemplo o *Segment Anything Model* (SAM), para melhorar a eficiência na avaliação, as métricas de precisão e *recall*.

Na visão computacional, a detecção de qualquer objeto é um fundamento relacionado a localização e classificação, porém, em dados visuais. A possibilidade de detecção de objetos em tempo real, interfere diretamente em aplicações para veículos autônomos, robótica, segurança, imagens da área da saúde e como principal foco deste estudo a agricultura, isso, estabelece a necessidade de aprimoramento no manejo e monitoramento de culturas e saúde das plantas, permitindo a relação direta com as redes neurais convolucionais (CNNs) no desempenho de velocidade e precisão (RANA; VAIDYA, 2026).

METODOLOGIA

Segue o fluxograma com o resumo metodológico:

Figura 1. Fluxograma metodológico do processo de desenvolvimento, treinamento, validação e avaliação dos modelos YOLOv11 para segmentação de folhas e estimativa automatizada da área foliar.



Fonte: Elaborado pelos autores.

Conjunto de Dados (Dataset)

O conjunto de dados utilizado neste estudo, foi composto por 555 imagens de folhas, adquiridas em ambiente controlado, com o objetivo de reduzir a variabilidade associada a fatores externos, como flutuações e iluminação, sombras, ruído de fundo e sobreposição de objetos. Essa padronização é particularmente relevante em estudos de segmentação de órgãos vegetais, nos

quais pequenas variações visuais podem impactar significativamente a qualidade do delineamento da máscara e, conseqüentemente, a estimativa de parâmetros morfométricos, como área e perímetro foliar (FRAN *et al.*, 2022).

As imagens foram anotadas manualmente para a tarefa de segmentação de instâncias (*instance segmentation*), considerando uma única classe de interesse a "folha". A anotação em nível de instância permitiu a geração de máscaras precisas, fundamentais para a avaliação da capacidade do modelo em distinguir corretamente o objeto de interesse do fundo, mesmo em regiões de borda e transição.

O *dataset* foi dividido aleatoriamente em dois subconjuntos: 70% recomendação, 15% validação e 15% teste. Essa divisão buscou garantir quantidade suficiente de dados para o aprendizado do modelo, ao mesmo tempo em que preservou um conjunto independente para avaliação do desempenho durante o treinamento. Para aumentar a robustez do modelo e reduzir riscos de *overfitting*, foram aplicadas técnicas de *data augmentation* durante o treinamento, incluindo ajustes de *blur*, *median blur*, conversão para escala de cinza e equalização adaptativa de histograma (*Contrast Limited Adaptive Histogram Equalization – CLAHE*) (YANG *et al.*, 2023). Essas estratégias simulam variações naturais frequentemente observadas em cenários reais de aquisição de imagens agrícolas e contribuem para melhorar a capacidade de generalização do modelo.

Arquitetura da Rede Neural

Foram avaliados cinco modelos da arquitetura YOLOv11, especificamente na versão de segmentação (-seg). A escolha desta arquitetura justifica-se pela sua capacidade de realizar, simultaneamente, a detecção do objeto e a segmentação precisa de seus contornos, combinando eficiência computacional com elevada acurácia espacial. Essa característica é especialmente relevante para aplicações agronômicas e de fenotipagem vegetal, nas quais o objetivo final não se limita à identificação da presença da folha, mas envolve a mensuração precisa de suas dimensões (HE *et al.*, 2025).

Foram comparadas as seguintes variantes: profundidade da rede, largura das camadas e número total de parâmetros, permitindo investigar o compromisso entre complexidade do modelo, custo computacional e desempenho na segmentação. As versões avaliadas foram: a) YOLO11n (*Nano*): $\approx$ 2,8 milhões de parâmetros; b) YOLO11s (*Small*): $\approx$ 10 milhões de

parâmetros; c) YOLO11m (*Medium*): $\approx 22,3$ milhões de parâmetros; d) YOLO11L (*Large*): $\approx 27,5$ milhões de parâmetros; e) YOLO11x (*Extra Large*): ≈ 62 milhões de parâmetros.

A comparação entre essas variantes permitiu avaliar como o aumento progressivo da capacidade representacional da rede impacta a qualidade da segmentação, especialmente nas regiões de borda da folha, que são críticas para o cálculo acurado da área foliar.

Configuração Experimental e Treinamento

Os experimentos foram conduzidos em ambiente computacional baseado na plataforma *Google Colab*, utilizando uma GPU NVIDIA Tesla T4 com suporte a operações de precisão mista (*Automatic Mixed Precision – AMP*), estratégia que permite acelerar o treinamento e reduzir o consumo de memória sem comprometer a estabilidade numérica.

Todos os modelos foram treinados por 200 épocas, número definido de modo a permitir a convergência adequada das funções de perda. O processo de otimização utilizou o otimizador AdamW, escolhido por sua capacidade de combinar adaptação dinâmica da taxa de aprendizado com regularização eficiente dos pesos, sendo amplamente empregado em tarefas de segmentação profunda (SHEN *et al.*, 2023). A taxa de aprendizado inicial foi ajustada automaticamente ($\text{lr0}=0.002$, $\text{momentum}=0.9$) e o tamanho do lote (*batch size*) foi mantido em 16 imagens.

A resolução de entrada das imagens foi padronizada em 640×640 *pixels* para os modelos YOLO11n, YOLO11s, YOLO11m e YOLO11L. Para a variante modelo YOLO11x, devido as limitações de memória da GPU disponível, a resolução foi ajustada para 480×480 *pixels* (isso significa que a resolução possui 480 pixels de largura por 480 pixels de altura).

Métricas de Avaliação

O desempenho dos modelos foi avaliado com base nas métricas padrão do protocolo COCO, amplamente adotado de estudos de detecção e segmentação de objetos. A métrica principal utilizada como critério de comparação foi o Mask mAP@50-95, que corresponde, a média da precisão média da máscara calculada em múltiplos limiares de Interseção sobre União – IoU – variando de 0,50 a 0,95) (AGNEW *et al.*, 2023).

A escolha da métrica é particularmente crítica neste estudo, uma vez que esta reflete não apenas a correta localização da folha, mas principalmente a qualidade geométrica do contorno

segmentado, aspecto diretamente relacionado à exatidão do cálculo de área foliar. Adicionalmente, foram avaliadas além da Precisão (P), a Revocação (R) e o tempo médio de inferência por imagem, permitindo uma análise integrada entre acurácia e eficiência computacional (ALMUFARED *et al.*, 2024).

Análise Estatística e Métricas de Desempenho

A avaliação quantitativa dos modelos baseou-se em métricas estatísticas derivadas da matriz de confusão, considerando os conceitos de Verdadeiros Positivos (TP), Falsos Positivos (FP) e Falsos Negativos (FN). Para a tarefa de segmentação de folhas, definiu-se: TP: *pixels* de folha corretamente classificados como folha; FP: *pixels* de fundo incorretamente classificados como folha; FN: *pixels* de folha incorretamente classificados como fundo.

A partir desses parâmetros, foram calculados a Precisão (P) e a Revocação (R), que mensuram, respectivamente, a confiabilidade das predições positivas e a capacidade do modelo em detectar a presença da folha e delinear corretamente sua área foliar. Essas métricas fornecem uma visão complementar ao mAP, permitindo interpretar o comportamento do modelo em termos de erro de supersegmentação ou subsegmentação (MÜLLER *et al.*, 2024). A Precisão indica a confiabilidade da detecção e a Revocação indica a sensibilidade do modelo em encontrar o objeto, ou seja, o resultado de alta precisão e alta revocação, indicam respectivamente poucas detecções erradas e poucos objetos reais perdidos.

Interseção sobre União (IoU) e Média da Precisão Média (mAP)

Para validar a precisão geométrica da segmentação, utilizou-se a métrica de Interseção sobre União (IoU), que quantifica a sobreposição entre a máscara predita pelo modelo Este, mede a sobreposição entre a máscara predita pelo modelo (A_{pred}) e a máscara de referência anotada manualmente (A_{gt}), considerado fator crítico para a posterior mensuração das dimensões da folha. Essa métrica é particularmente relevante em estudos voltados à mensuração morfológica, pois penaliza erros nas regiões de borda, onde pequenas discrepâncias podem gerar diferenças significativas no cálculo da área (CHENG *et al.*, 2021).

A métrica global utilizada para comparação e seleção do melhor modelo foi a média da precisão média (*mean Average Precision* – mAP), seguindo o protocolo padrão do *dataset*

COCO. Foram considerados: 1) mAP@50: considera uma predição correta se o IoU > 0,50 (adota um critério mais permissivo de sobreposição); 2) mAP@50-95: métrica rigorosa que calcula a média do mAP em dez limiares de IoU, variando de 0,50 a 0,95 com passos de 0,05 (ALMUFARED *et al.*, 2024). Neste estudo, o mAP@50-95 para máscaras foi o critério determinante, por refletir de forma mais fiel a aderência estatística do contorno segmentado à borda real da folha.

A utilização do mAP@50-95 para as máscaras de segmentação foi o critério determinante neste estudo, em que $t = 0.5 = \text{IoU} = 0,5$, mostra que 50% da área prevista pelo modelo equivale com a área real, neste caso, do objeto “folha”. Se a IoU entre a predição e a referência for $\geq 0,5$, a detecção é considerada correta, mas, se for $< 0,5$, a detecção é considerada incorreta. Um valor alto nesta métrica indica que o modelo não apenas localizou a folha, mas que o contorno desenhado pela rede neural possui uma aderência estatística extremamente alta à borda real do objeto, minimizando erros no cálculo de área e perímetro e chegando a acurácia.

Funções de Perda (*Loss Functions*)

Durante o treinamento, a convergência estatística dos modelos foi monitorada através da minimização de três funções de perda compostas, responsáveis por diferentes aspectos do aprendizado: a) *Box Loss* (L_{box}): erro associado às coordenadas da caixa delimitadora; b) *Seg Loss* (L_{seg}): erro associado à classificação *pixel-a-pixel* da máscara, conhecida como entropia cruzada binária; c) *Classification Loss* (L_{cls}): erro de classificação da probabilidade da classe “folha”. E ainda, acrescentando a *Distribution Focal Loss* (*DFL Loss* - L_{df}), utilizada para refinar a precisão das bordas em caixas delimitadoras, contribuindo para uma melhor localização espacial do objeto (TERVEN *et al.*, 2023).

RESULTADOS E DISCUSSÃO

O treinamento do modelo de rede neural convolucional, baseado na arquitetura YOLOv11s-seg (*Small Segmentation*), foi conduzido ao longo de 200 épocas utilizando um conjunto de dados composto por 503 imagens de treinamento e 52 imagens de validação. O processo foi acelerado por *hardware* dedicado (*GPU Tesla T4*), resultando em um tempo total de treinamento de aproximadamente 0,96 horas, equivalente a 57,6 minutos ou 3.456 segundos.

A análise das métricas de desempenho final, obtidas através da validação dos pesos ótimos (*best.pt*), demonstra uma alta capacidade de generalização do modelo. Para a tarefa de segmentação de instâncias, o modelo alcançou uma Precisão de 98% e uma Revocação (*Recall*) de 96,2%. Estes valores indicam um equilíbrio robusto entre a capacidade do modelo de identificar corretamente os objetos de interesse (poucos falsos positivos) e a sua habilidade em encontrar a quase totalidade das instâncias presentes nas imagens (poucos falsos negativos). Estes resultados comparados aos estudos de Wang *et al.* (2026), mostram que o YOLO11s é competitivo, mas que aprimorados, neste caso YOLO11s-APFAN, podem surtir efeitos de ganhos claros de acurácia, mantendo velocidade adequada para que possa usar em tempo real.

A métrica mAP@0.5 (*mean Average Precision com limiar de IoU de 50%*) atingiu 98,5% para as máscaras de segmentação e 99,1% para as caixas delimitadoras (*bounding boxes*). Mais significativamente, o mAP@0.5-0.95, uma métrica rigorosa que avalia a precisão do recorte da segmentação em vários limiares de sobreposição, registrado em 95,6%. Este alto índice no mAP de máscaras, valida a eficácia do modelo para aplicações que exigem a mensuração precisa da área do objeto, como a estimativa da área foliar, como representado na figura 2 (A e B).

Figura 2. Treinamento da métrica da área foliar. A) leitura da foto da folha. B) leitura da digitalização da folha.



Fonte: Elaborada pelos próprios autores.

Em termos de eficiência computacional, o modelo apresentou um tempo médio de

inferência de 8,5ms por imagem (pré-processamento de 0,2ms e pós-processamento de 2,8ms), o que viabiliza sua aplicação em sistemas de processamento em tempo real. As curvas de perda (*losses*) apresentaram convergência estável, com a perda de segmentação (*segloss*) finalizando em aproximadamente 0,28, evidenciando um aprendizado consistente das características morfológicas dos objetos.

Os resultados quantitativos indicam que o modelo opera com taxa de erro de apenas 2% nas detecções e 3,8% nas omissões. A acurácia das caixas delimitadoras apresenta redução inferior a 1% em relação ao desempenho ideal, enquanto a precisão segmentada mantém variação de apenas 1,5%. Sob critérios progressivamente mais rigorosos de IoU, o desempenho reduz-se apenas 4,4 pontos percentuais, mantendo estabilidade estatística. O sistema processa em média 117 imagens por segundo, com apenas 2,35% do tempo destinado ao pré-processamento.

No quadro 1 apresenta o desempenho comparativo das cinco variantes da arquitetura YOLOv11 avaliadas neste estudo após 200 épocas de treinamento, considerando métricas de precisão da segmentação, eficiência computacional e complexidade do modelo. Os resultados evidenciam diferenças relevantes entre as variantes, permitindo uma análise aprofundada do equilíbrio entre acurácia e custo computacional na estimativa automatizada da área foliar. O que pode ser comparado aos resultados de Mendes *et al.* (2025) em que o YOLO11 mostra-se eficaz para o pré-processamento de imagens de folhas de oliveira, podendo detectar e segmentar as folhas com precisão, mesmo que entre as variantes que foram testadas, o YOLO11n tenha se destacado com as melhores métricas de performance.

Quadro 1. Comparativo de desempenho dos modelos de segmentação YOLOv11.

Modelo	Parâmetros (M)	Tempo de Treino (h)	Tempo de Inferência (ms)	Mask mAP (50–95)	Precisão (P)	Recall (R)
YOLO11n	2.8	0.81	5.5	0.929	0.961	0.942
YOLO11s	10.0	0.96	8.5	0.956	0.980	0.962
YOLO11m	22.3	1.74	16.2	0.937	0.970	0.925
YOLO11l	27.5	1.96	18.8	0.938	0.960	0.925
YOLO11x*	62.0	2.28	19.5	0.917	0.961	0.942

Nota: *, o modelo YOLO11x foi treinado com resolução reduzida (480×480 pixels) devido às limitações de hardware.

Nota: destaque em negrito, escolha do modelo do YOLO conforme as variantes analisadas.

Fonte: elaborado pelos próprios autores.

Desempenho da Segmentação e Precisão Geométrica das Máscaras

Os resultados demonstraram que o aumento da complexidade do modelo, expresso pelo

número de parâmetros, não resultou em ganho linear de desempenho na segmentação das folhas. Entre as variantes avaliadas, o modelo YOLO11s (*Small*) apresentou o melhor desempenho global, alcançando um valor de Mask mAP@50–95 de 95,6%, além de elevados índices de Precisão e Revocação, respectivamente, 98% e 96,2%.

Esse desempenho indica que a variante *Small* possui capacidade de generalização adequada ao problema, conseguindo delinear com elevada fidelidade as bordas foliares em um cenário de classe única. A elevada pontuação em mAP@50–95 é particularmente relevante neste estudo, pois essa métrica avalia a qualidade da máscara sob múltiplos limiares de IoU, refletindo diretamente a aderência do contorno segmentado à borda real da folha, um fator determinante para a mensuração precisa da área foliar.

Por outro lado, os modelos de maior porte (YOLO11m e YOLO11l), apesar de possuírem mais que o dobro de parâmetros em relação ao YOLO11s, apresentaram leve redução no desempenho da segmentação, com valores de mAP@50–95 próximos a 93,7–93,8%. Esse comportamento sugere que, para problemas com morfologia bem definida e baixa variabilidade semântica, como a segmentação de folhas em imagens controladas, arquiteturas excessivamente profundas podem não trazer benefícios proporcionais, além de aumentar o custo computacional e o risco de aprendizado de padrões redundantes.

O modelo YOLO11x, que possui a maior complexidade entre as variantes avaliadas, apresentou o menor desempenho global, com 91,7%. Esse resultado está diretamente associado à redução da resolução de entrada para 480×480 pixels, necessária devido às limitações de memória da GPU utilizada. Esse achado reforça que, para tarefas de segmentação que exigem precisão em bordas finas e contornos irregulares, como as folhas, a resolução espacial da imagem exerce influência mais significativa na qualidade da segmentação do que o número absoluto de parâmetros do modelo. Assim como nos estudos de Buczynski, Kaplan e Jarosz (2025), todos os modelos do *software* YOLO utilizados, apresentaram alta precisão e robutez, tendo valores altos e próximo entre si para P, R, mAP@0.5, mAP@0.5-0.95 e F1-score, o que indica maturidade na arquitetura da inteligência artificial utilizada.

Eficiência Computacional e Viabilidade de Aplicação

Em termos de eficiência computacional, observou-se uma relação clara entre o tamanho do modelo e o tempo de inferência. O modelo YOLO11n (Nano) destacou-se como o mais rápido,

com tempo médio de inferência de 5,5 ms por imagem, equivalente a aproximadamente 180 quadros por segundo (FPS) na GPU Tesla T4. Mesmo com arquitetura compacta, o modelo manteve um desempenho competitivo, com Mask mAP@50–95 de 92,9%.

Esse resultado indica que o YOLO11n apresenta grande potencial para aplicações embarcadas e em tempo real, como monitoramento agrícola por drones, sistemas móveis ou dispositivos com restrições de processamento. Entretanto, a leve perda de precisão na segmentação em relação ao YOLO11s pode impactar negativamente a exatidão do cálculo da área foliar em estudos que demandam alta precisão métrica.

Em GPU de alto desempenho, como o RTX 5080, o modelo YOLOv8s foi o mais rápido nas análises de Buczynski, Kaplan e Jarosz (2025), com maior FPS e menor latência. Já o YOLOv9s foi o mais lento, mas apresentou boa acurácia. Para o YOLO11s e YOLOv10s destacou pela velocidade e precisão, com alto desempenho e com custo computacional considerável.

Considerando o objetivo principal deste trabalho, relacionando a estimativa automatizada e precisa da área foliar, o modelo YOLO11s foi selecionado como a arquitetura mais adequada. Essa variante apresentou o melhor compromisso entre qualidade da segmentação, estabilidade estatística e tempo de resposta, com inferência média de 8,5 ms por imagem, valor plenamente compatível com aplicações em laboratório e em sistemas de fenotipagem de alta vazão.

Implicações Agronômicas e Comparação com a Literatura

Os resultados obtidos neste estudo corroboram achados recentes da literatura que indicam a superioridade de abordagens baseadas em segmentação por máscara em relação a métodos tradicionais ou baseados apenas em caixas delimitadoras para a estimativa da área foliar. Trabalhos como os de Ribeiro *et al.* (2025) e Suarez, Blaser e Sutton (2025) destacam que erros na delimitação do contorno da folha representam uma das principais fontes de imprecisão na mensuração da área, especialmente em folhas com margens irregulares. Nas investigações de Rana e Vaidya (2026), o *software* YOLO foi indicado para aplicações práticas, especialmente quando é necessário combinar acurácia elevada com velocidade de processamento, indicando eficiência e precisão na detecção automática de alvos agrícolas e biológicos.

O elevado desempenho do YOLO11s em mAP@50–95 sugere que o protocolo proposto é capaz de minimizar esses erros geométricos, oferecendo uma alternativa não destrutiva, rápida

e altamente reprodutível aos métodos tradicionais de mensuração da área foliar. Além disso, a possibilidade de automatização em larga escala posiciona essa abordagem como uma ferramenta promissora para aplicações em fenotipagem vegetal, manejo agrícola de precisão e programas de melhoramento genético.

Limitações do Estudo

Independente do modelo YOLO11s ter tido uma alta acurácia, observamos algumas limitações: a) dependência da qualidade e diversidade do conjunto de dados, ou seja, iluminação extrema, oclusões, ruído e folhas danificadas podem comprometer a generalização do modelo; b) custo computacional e escalabilidade, em que a automatização em larga escala pode demandar recursos computacionais específicos, principalmente em dispositivos com *hardware* limitado.

CONCLUSÃO

Conclui-se que os resultados demonstram que modelos intermediários, bem ajustados ao problema que deseja ser solucionado, podem superar arquiteturas maiores e mais complexas quando o objetivo é a segmentação precisa de estruturas vegetais com morfologia definida. A escolha do YOLO11s como modelo final reflete a importância de se considerar não apenas a capacidade teórica da rede neural, mas também a resolução das imagens, o custo computacional e a finalidade agrônômica da aplicação, além do tempo resposta de retorno a leitura da área foliar.

A escolha e o alto desempenho nas métricas estatísticas demonstram que o modelo é adequado para o objetivo experimental de desenvolver um *software* para leitura de área foliar, apresentando confiabilidade na identificação, validação da acurácia geométrica, viabilidade em tempo real de rodagem do *software* e a convergência estável, não havendo super ajuste, neste caso, o processo de aprendizagem foi estatisticamente bem-sucedido.

Espera-se que para as futuras continuações do estudo, haja melhoramento do modelo YOLO11s, chegando a 100% da acurácia, abrangendo não apenas a área foliar, mas a planta como um todo.

REFERÊNCIAS

- AGNEW, C.; EISING, C.; DENNY, P.; SCANLAN, A.; VAN DE VEN, P.; GRUA, E. Quantifying the Effects of Ground Truth Annotation Quality on Object Detection and Instance Segmentation Performance. **IEEE Access**, v. 11, p. 25174-25188, 2023. DOI: <https://doi.org/10.1109/access.2023.3256723>.
- ALMUFAREH, M.; IMRAN, M.; KHAN, A.; HUMAYUN, M.; ASIM, M. Automated Brain Tumor Segmentation and Classification in MRI Using YOLO-Based Deep Learning. **IEEE Access**, v. 12, p. 16189-16207, 2024. DOI: <https://doi.org/10.1109/access.2024.3359418>.
- BAI, K.; ZHANG, Y.; SU, D.; QUIN T.; PENG, Z. Peanut Leaf Disease Detection Method Based on Improved YOLO v8n. **Transactions of the Chinese Society for Agricultural Machinery**, v. 56, n. 6, 2025. DOI: 10.6041/j.issn.1000-1298.2025.06.048.
- BÖKLE, Sebastian; GSCHEIDLE, Michael; WEIS, Martin; PARAFOROS, Dimitrios S.; GRIEPENTROG, Hans W. A concept of a decentral server infrastructure to connect farms, secure data, and increase the resilience of digital farming. **Smart Agricultural Technology**, v. 10, 100701, 2025. DOI: <https://doi.org/10.1016/j.atech.2024.100701>.
- BUCZYNSKI, K.; KAPŁAN, M.; JAROSZ, Z. Detection of Red, Yellow, and Purple Raspberry Fruits Using YOLO Models. **Agriculture**, v.15, n. 24, 2530, 2025. DOI: <https://doi.org/10.3390/agriculture15242530>.
- BRÉDA, Nathalie J. J. Ground-based measurements of leaf area index: a review of methods, instruments and current controversies. **Journal of experimental botany**, v. 54, n. 392, 2003: 2403-17. DOI:10.1093/jxb/erg263.
- FAN, X.; ZHOU, R.; TIAHJADI, T.; CHOUDHURY, S.; YE, Q. A Segmentation-Guided Deep Learning Framework for Leaf Counting. **Frontiers in Plant Science**, v. 13, 2022. DOI: <https://doi.org/10.3389/fpls.2022.844522>.
- FANOURAKIS, Dimitrios; KAZAKOS, Filippops; NEKTARIOS, Panayiotis A. Allometric Individual Leaf Area Estimation in Chrysanthemum. **Agronomy**, v. 11, n. 4: 795, 2021. DOI: <https://doi.org/10.3390/agronomy11040795>.
- HE, L.; ZHOU, Y.; LIU, L.; CAO, W.; MA, J. Research on object detection and recognition in remote sensing images based on YOLOv11. **Scientific Reports**, v. 15, n. 14032, 2025. DOI: <https://doi.org/10.1038/s41598-025-96314-x>.
- KHAN, A.; JENSEN, S. LEAF-Net: A Unified Framework for Leaf Extraction and Analysis in Multi-Crop Phenotyping Using YOLOv11. **Agriculture**, v. 15, n. 2, 2025. DOI: <https://doi.org/10.3390/agriculture15020196>.
- MADADUM, H.; NASIR, F. E.; HARUEHANSAPONG, K. Optimizing watermelon leaf disease detection using Sam-based augmentation with YOLO for practical agricultural solutions. **Smart Agricultural Technology**, v. 12, 2025. DOI: <https://doi.org/10.1016/j.atech.2025.101326>.

MENDES, J.; LIMA, J.; RODRIGUES, N.; PEREIRA, A. I. **Automated Preprocessing of Olive Leaf Images for Cultivar Classification Using YOLO11**. Conferece paper: Optimization, Learning Algorithms and Applications, p. 286-297, 2025. DOI: 10.1007/978-3-032-00137-5_20.

MU, Youying; HE, Ke; SHI, Peijian; WANG, Lin; DENG, Linli; SHI, Zhuyue; LIU, Mengdi; NIKLAS, Karl J. Comparison between computer recognition and manual measurement methods for the estimation of leaf area. **Annals of Botany**, v. 134, ed. 3, p. 501-510, 2024. DOI: <https://doi.org/10.1093/aob/mcae090>.

MÜLLER, D.; SOTO-REY, I.; KRAMER, F. Towards a guideline for evaluation metrics in medical image segmentation. **BMC Research Notes**, 15, n. 210, 2022. DOI: <https://doi.org/10.1186/s13104-022-06096-y>.

RANA, A., VAIDYA, P. YOLO-based deep learning framework for real-time multi-class plant health monitoring in precision agriculture. **Scientific Reports**, v. 16, n. 197, 2026. DOI: <https://doi.org/10.1038/s41598-025-29132-w>.

RIBEIRO, J. E. D. S.; COELHO, E. S.; SILVA, G. C.; OLIVEIRA, P. H. A.; SILVA, E. F.; SANTOS, G. L.; OLIVEIRA, A. K. S.; LIMA, J. V. L.; PEREIRA, W. E.; SILVEIRA, L. M.; BARROS, A. P. Non-Destructive Methods Based on Machine Learning for the Prediction of Sweet Potato Leaf Area: A Comparative Approach. **IEEE Access**, v. 13, p. 47389–47405, 2025. DOI: <https://doi.org/10.1109/access.2025.3551270>.

RIBEIRO, J. E. S.; SILVA, A. G. C.; OLIVEIRA, P. H. A.; OLIVEIRA, J. M. S.; SILVA, A. N.; LIMA, J. V. L.; SILVA, I. E.; COELHO, E. S.; LEITE, I. O.; SILVA, E. F.; SILVA, T. I.; SILVEIRA, L. M.; JÚNIOR, A. P. B. Machine Learning for Non-Destructive Prediction of Sunflower Leaf Area. **IEEE Access**, v. 13, p. 137761–137772, 2025. DOI: <https://doi.org/10.1109/access.2025.3595153>.

SALKA, T. D.; HANAFI, M. B.; RAHMAN, S. M. S. A. A.; ZULPERI, D. B. M.; OMAR, Z. Plant leaf disease detection and classification using convolution neural networks model: a review. **Artificial Intelligence Review**, v. 58, n. 322, 2025. DOI: <https://doi.org/10.1007/s10462-025-11234-6>.

SUAREZ, Emilio; BLASER, Manuel; SUTTON, Mary. Automating Leaf Area Measurement in Citrus: The Development and Validation of a Python-Based Tool. **Applied Sciences**, v. 15, n. 17: 9750, 2025. DOI: <https://doi.org/10.3390/app15179750>.

SCHRADER, Julian; SHI, Peijian; ROYER, Dana L.; PEPPE, Daniel J.; GALLAGHER, Rachael V.; LI, Yirong; WANG, Rong; WRIGHT, Ian J. Leaf size estimation based on leaf length, width and shape. **Annals of Botany**, v. 128, n. 4, p. 395-406. DOI: <https://doi.org/10.1093/aob/mcab078>.

SHEN, L.; TAO, H.; NI, Y.; WANG, Y.; STOJANOVIC, V. Improved YOLOv3 model with feature map cropping for multi-scale road object detection. **Measurement Science and Technology**, v. 34. 2023. DOI: <https://doi.org/10.1088/1361-6501/acb075>.

TERVEN, J.; CÓRDOVA-ESPARZA, D.; ROMERO-GONZÁLEZ, J.; RAMÍREZ-PEDRAZA, A.; CHÁVEZ-URBIOLA, E. A comprehensive survey of loss functions and metrics in deep learning. **Artificial Intelligence Review**, v. 58, n. 195, 2023. DOI: <https://doi.org/10.1007/s10462-025-11198-7>.

WANG, Z.; LI, W.; FAN, Y.; WANG, L.; YAO, G. Ship target detection algorithm in remote sensing images based on improved YOLO11s. **Ocean Engineering**, v. 343, parte 3, 2026. DOI: <https://doi.org/10.1016/j.oceaneng.2025.123204>.

YANG, T.; ZHOU, S.; XU, A.; YE, J.; YIN, J. An Approach for Plant Leaf Image Segmentation Based on YOLOV8 and the Improved DEEPLABV3+. **Plants**, v. 12, n. 19, 2023. DOI: <https://doi.org/10.3390/plants12193438>.

YU, Xiaojing; SHI, Peijian; SCHRADER, Julian; NIKLAS, Karl J. Nondestructive estimation of leaf area for 15 species of vines with different leaf shapes. **American Journal of Botany**, v. 107, n. 11, p. 1481–1490, 2020. DOI: <https://doi.org/10.1002/ajb2.1560>.

ZHANG, Y.; LI, Y.; CAO, X.; WANG, Z.; CHEN, J.; LI, Y.; ZHONG, Z.; BAI, R.; YANG, P.; PAN, F.; FU, X. Leaf area estimation in small-seeded broccoli using a lightweight instance segmentation framework based on improved YOLOv11-AreaNet. **Frontiers in Plant Science**, v. 16, 2025. DOI: <https://doi.org/10.3389/fpls.2025.1622713>.

ZHAO, X.; YANG, M.; ZHANG, Y. Apple Leaf Disease Detection Method Based on Improved YOLO v10n. **Transactions of the Chinese Society for Agricultural Machinery**, v. 56, n. 9, p. 657-666, 2025. DOI: 10.6041/j.issn.1000-1298.2025.09.056.